

Posicionamento de sensores para monitoramento colaborativo de emergências urbanas

Gabriel S. Barreto¹, Matheus G. Pires¹ e Thiago C. Jesus¹

¹PGCC / DEXA / DTEC - UEFS, Universidade Estadual de Feira de Santana, Brasil

gabrielalves@ecomp.uefs.br, mgpires@ecomp.uefs.br, tcjesus@uefs.br

Abstract. *This paper proposes a methodology based on the multi-objective genetic algorithm NSGA-II for the optimized placement of scalar and visual sensors in collaborative monitoring networks designed for urban emergency detection. The solution simultaneously addresses spatial coverage, sensing quality and redundancy, and network connectivity criteria. Experimental results indicate that the proposed methodology effectively balances multiple optimization objectives, ensuring extensive coverage of the region of interest, appropriate redundancy levels, and robust connectivity to enable effective collaboration among sensors.*

Resumo. *Este trabalho propõe uma metodologia baseada no algoritmo genético multiobjetivo NSGA-II para posicionamento otimizado de sensores escalares e visuais em redes colaborativas de monitoramento de emergências urbanas. A solução considera, simultaneamente, critérios de cobertura espacial, qualidade e redundância de sensoriamento, e conectividade em rede. Resultados experimentais mostraram que a metodologia proposta alcança equilíbrio satisfatório entre os múltiplos objetivos analisados, garantindo boa cobertura da área de interesse, níveis adequados de redundância e conectividade robusta para colaboração efetiva entre sensores.*

1. Introdução

Emergências urbanas, como incêndios, enchentes e acidentes em vias de tráfego, apresentam risco significativo de perdas humanas e materiais. Devido às características imprevisíveis desses eventos, a rapidez e a precisão na coleta de dados de campo são cruciais para que as autoridades elaborem contramedidas eficientes. A fim de suprir tal demanda, *Redes de Sensores Sem Fio* (RSSF) têm ganhado espaço em aplicações de *Internet das Coisas* (IoT), oferecendo monitoramento contínuo das condições de uma região [Fei et al. 2017]. Ainda assim, questões como limitações de energia, interferências no sinal e restrições de cobertura tornam a implantação dessas redes um desafio complexo [El-Sherif et al. 2018].

A proposta de *Sistemas Colaborativos* tem ganhado fôlego em pesquisas voltadas à detecção de emergências urbanas. Em essência, esses sistemas viabilizam a troca e a consolidação de informações provenientes de dispositivos espalhados em campo, de

Este trabalho foi apoiado pelo Programa Interno de Auxílio Financeiro aos Programas de Pós-Graduação Stricto Sensu (AUXPPG) da UEFS e pelo Programa de Apoio à Pós-Graduação (PROAP) da CAPES.

forma descentralizada, para gerar alertas e orientar a tomada de decisão, contribuindo para uma leitura mais confiável do ambiente [Wu et al. 2020].

No contexto das RSSF, o aspecto colaborativo emerge à medida que cada nó sensor, capaz de coletar parâmetros ambientais (temperatura, umidade, concentração de gases etc.), troca dados ou metadados com seus vizinhos e/ou com estações de análise. Assim, possíveis falhas de leitura ou situações de bloqueio de sinal podem ser compensadas pela informação de outros sensores, enriquecendo a qualidade dos dados agregados [Chen et al. 2020]. Essa colaboração efetiva demanda, contudo, que os sensores sejam estrategicamente posicionados — tanto para otimizar a cobertura quanto para garantir conectividade suficiente a fim de viabilizar a troca de informações.

A partir desse cenário, o presente trabalho propõe uma nova formulação de posicionamento que considera o posicionamento colaborativo de sensores, visando maximizar a detecção de eventos em regiões urbanas e fornecer bases sólidas para respostas ágeis e eficazes. Assim, este trabalho propõe aplicar algoritmos genéticos para posicionar sensores de forma a criar uma rede de comunicação que potencialize a colaboração entre unidades de detecção de emergências urbanas, considerando a extensão da área monitorada, a qualidade de sensoriamento e a qualidade da conectividade em rede. É considerado que as RSSF são compostas tanto por sensores escalares quanto visuais, a fim de gerar mais diversidade e conhecimento sobre os dados gerados, reforçando o potencial de colaboração.

O artigo está organizado como segue. Na seção 2, revisamos a literatura relacionada a posicionamento de sensores, cobertura colaborativa de sensores visuais e escalares, bem como soluções multiobjetivo com algoritmos genéticos. Na seção 3, apresentamos a modelagem proposta para o posicionamento dos sensores. Na seção 4, descrevemos os resultados alcançados em uma avaliação experimental. Finalmente, na seção 5, concluímos o artigo e apontamos as direções para trabalhos futuros.

2. Revisão de Literatura e Trabalhos Relacionados

As emergências urbanas exigem ações ágeis e articuladas, muitas vezes sob alta pressão, para minimizar danos e proteger a população. Nesse sentido, a detecção antecipada de situações de risco torna-se prioritária para apoiar as autoridades responsáveis. Pesquisas recentes apontam para uma convergência entre tecnologias de *Internet das Coisas* (IoT) e abordagens colaborativas no âmbito do desenvolvimento de plataformas que aliem métodos confiáveis de captura de dados em campo, com a disseminação e consolidação colaborativa dessas informações [Coelho et al. 2023].

A arquitetura das *Redes de Sensores Sem Fio* sustenta grande parte das aplicações de monitoramento em IoT, atuando como infraestruturas para coleta e transmissão dos dados. Em ambientes urbanos, essas redes se deparam com fatores que vão desde obstruções físicas (prédios, muros) até interferências de sinais e alto dinamismo de eventos [Fei et al. 2017]. Nesse cenário, o posicionamento dos sensores tem relevância crítica, pois impacta diretamente a cobertura espacial e a qualidade das informações geradas. Por exemplo, uma cobertura deficiente em áreas de risco pode impedir a detecção de emergências, da mesma forma que sensores demasiadamente concentrados em um só ponto podem gerar redundância de dados e desperdiçar recursos energéticos.

2.1. Posicionamento de Sensores e Cobertura Colaborativa

Para garantir que a coleta de dados em campo seja eficiente, estudos de posicionamento de sensores usualmente consideram (i) a **cobertura de área**, ou seja, quantos pontos da região de interesse podem ser monitorados; (ii) a **qualidade** do sensoriamento, que depende da sensibilidade, do alcance e da redundância dos dispositivos; e (iii) o **acesso à comunicação**, fundamental para agregar e distribuir as informações coletadas [Fei et al. 2017, Binh et al. 2018]. Em cenários urbanos, a presença de edificações e o dinamismo do tráfego afetam significativamente a transmissão sem fio, tornando essencial a seleção apropriada dos locais de implantação dos sensores [Benatia et al. 2017].

Com efeito, a colaboração entre nós sensores só se concretiza se houver caminhos de comunicação robustos, capazes de retransmitir alertas e consolidar leituras em nós de análise. Alguns autores têm proposto otimizar cobertura e a qualidade de sensoriamento simultaneamente, empregando algoritmos de natureza bioinspirada (por exemplo, *Cuckoo Search*, *Particle Swarm Optimization*) ou meta-heurísticas evolucionárias como o *Non-dominated Sorting Genetic Algorithm II* (NSGA-II) [Hanh et al. 2019, El-Sherif et al. 2018]. Essas abordagens lidam com o caráter multiobjetivo do problema, explorando soluções que equilibrem a maximização de área coberta e a garantia de acurácia das informações coletadas. Entretanto, ainda há uma lacuna referente às garantias de um grau mínimo de *colaboração* entre os sensores.

2.2. Sensores Visuais e Integração com Sensores Escalares

Além dos sensores escalares, que coletam variáveis ambientais, o uso de sensores visuais (câmeras) agrega riqueza de dados ao processo de detecção de emergências, pois permite identificar situações que vão além de simples leituras numéricas [Rangel et al. 2019]. Entretanto, a configuração de câmeras apresenta um desafio adicional: determinar não apenas onde alocá-las, mas também como orientá-las, dado que ângulos de visão e obstáculos em linha de visada podem excluir regiões importantes do monitoramento [Jesus et al. 2019]. Nesse sentido, há esforços voltados à integração de sensores escalares e visuais, potencializando o poder de detecção por meio de sobreposição de leituras distintas.

O caráter colaborativo também se manifesta quando câmeras e sensores de diferentes tipos trocam informações para refinar ou descartar falsos positivos. Um sensor escalar pode indicar possível aumento rápido de temperatura, ao passo que uma câmera próxima valida ou contradiz tal leitura ao analisar imagens do local. Dessa forma, o sistema global obtém maior robustez e menor incidência de alarmes injustificados [Wu et al. 2020].

2.3. Algoritmos Evolutivos e Multiobjetivo no Posicionamento Colaborativo

A fim de otimizar parâmetros como cobertura, conectividade e qualidade de sensoriamento de maneira simultânea, algoritmos evolutivos vêm sendo amplamente investigados [Fei et al. 2017, El-Sherif et al. 2018]. Destaca-se o NSGA-II, utilizado em diversos trabalhos por apresentar boa eficiência na busca de soluções de Pareto em problemas multiobjetivo. Essa técnica parte de uma população inicial de configurações de sensores, avaliando em cada geração a adequação de cada *indivíduo* (posicionamento) segundo múltiplas funções de avaliação. Com isso, é possível gerar um conjunto de soluções que equilibram esses critérios, e cabe ao especialista ou órgão responsável pela aplicação escolher

a configuração que melhor atenda às prioridades do momento (por exemplo, máxima cobertura em detrimento de algum custo, ou máxima confiabilidade de comunicação mesmo que cubra menos área).

Desse modo, embora diversos trabalhos já tenham investigado algoritmos evolutivos para posicionamento de sensores e abordagens colaborativas em RSSF, a maioria concentra-se em objetivos específicos (cobertura ou conectividade) ou em configurações restritas de sensores. Em contraste, a proposta aqui apresentada traz uma metodologia integrativa que considera, de forma simultânea, o alcance espacial (*cobertura de área*), a *qualidade de sensoriamento* (tanto de sensores escalares quanto visuais), a *redundância* necessária para evitar falhas e a *qualidade de conectividade* que suporta a colaboração entre nós. Essa combinação de múltiplos critérios potencializa um ambiente colaborativo robusto para detecção de emergências urbanas, pois explora não apenas a existência de diferentes tipos de sensores, mas também a maneira como eles podem se comunicar e complementar mutuamente, elevando a precisão dos alertas e a efetividade da resposta em cenários críticos.

3. Solução Proposta

Para viabilizar a otimização do posicionamento dos sensores, deve-se conhecer previamente a localização, distribuição e cobertura geográfica das redes de comunicação onde eles estão inseridos, a fim de definir a estratégia mais adequada para o processo de posicionamento. Assim, uma Região de Interesse (RdI) é mapeada pela subdivisão da área total em pequenas células de tamanho fixo [Bouid et al. 2020, Costa et al. 2019], denominadas Blocos de Área (*Area Blocks - AB*), com altura (h_{sAB}) e largura (w_{sAB}) fixas.

A Figura 1 ilustra a representação de uma área genérica mapeada por essa abordagem. Toda RdI é delimitada pelo retângulo externo, que é subdividido em ABs com dimensões $w_{sAB} \times h_{sAB}$. Com essa delimitação e utilizando a estratégia proposta por [Jesus et al. 2023], pode-se definir um conjunto de redes sem fio $NT = \{net_1, net_2, \dots, net_n\}$ presentes na RdI, sendo (X_{AP_j}, Y_{AP_j}) as coordenadas X e Y do ponto de acesso (*access point*) da j-ésima rede; R_j o raio de cobertura da j-ésima rede; e T_j o tipo da j-ésima rede (e.g., WiFi, 4G, LoRa, entre outros).

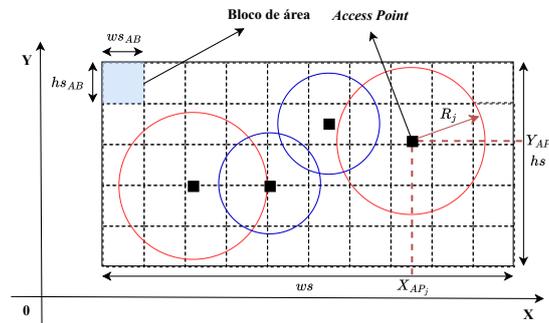


Figura 1. Representação da Região de Interesse.

Com essas informações, o i-ésimo AB é considerado coberto pela j-ésima rede se o ponto central do AB estiver dentro do alcance definido por R_j . Formalmente, a distância euclidiana entre as coordenadas do ponto de acesso da rede e o ponto central do AB_i deve ser menor que R_j , conforme descrito na Equação 1. É importante destacar que um AB

pode ser coberto por mais de uma rede simultaneamente, o que aumenta a conectividade na área e possibilita uma comunicação mais robusta [Jesus et al. 2023].

$$cov_{AB}(AB_i, net_j) = \begin{cases} 1, & d(AB_i, net_j) \leq R_j \\ 0, & c.c \end{cases} \quad (1)$$

3.1. Modelagem de qualidade de conectividade

Uma vez posicionadas as redes, pode-se utilizar a métrica *Dependable-Quality Connectivity (DPConn)* [Jesus et al. 2023] para avaliar a qualidade da conectividade em cada AB. Essa métrica permite verificar se a disposição das redes atende aos requisitos relacionados ao tráfego de dados, integridade, autenticidade e tolerância a falhas dos dispositivos de monitoramento. A definição formal da variável *DPConn* é apresentada na Equação 2.

$$DPConn(AB_i) = \frac{\sum_{j=1}^n [cov_{AB}(AB_i, net_j) \cdot (S \cdot s_j + T \cdot t_j + R \cdot r_j - C \cdot c_j)]}{\sum_{j=1}^{|type|} [S \cdot s_j + T \cdot t_j + R \cdot r_j - C \cdot c_j]} \quad (2)$$

As seguintes especificações estão relacionadas à Equação 2:

- n - número de redes implantadas;
- $|type|$ - número de diferentes tipos de redes;
- $cov_{AB}(AB_i, net_j)$ - Veja a Equação 1
- S - peso associado ao parâmetro de nível de Segurança;
- T - peso associado ao parâmetro de *Throughput*;
- R - peso associado ao parâmetro de Confiabilidade;
- C - peso associado ao parâmetro de Custo;
- s_j, t_j, r_j, c_j - indicam os níveis de Segurança, *Throughput*, Confiabilidade e Custo, respectivamente, para a j -ésima rede;

3.2. Modelagem de qualidade de sensoriamento

Em relação ao modelo representativo para os dispositivos de monitoramento, considera-se que os sensores são escalares ou visuais (câmeras). Assim, é imprescindível considerar informações como o tipo do dispositivo, raio de sensoriamento, raio de comunicação, modelo de sensoriamento e quantidade, de forma a estabelecer uma representação adequada para o conjunto de dispositivos que serão posicionados ao longo de uma RdI.

Este trabalho propõe a utilização de um modelo de sensoriamento baseado nos padrões Binário e Probabilístico, apresentado na Equação 3a. Esse modelo apresenta um decaimento linear a partir de um limiar estabelecido, (ver Figura 2(a)), se aproximando do comportamento dos sensores lineares. Desta forma, quanto maior a distância euclidiana entre um sensor e um ponto específico (ver Equação 3b), menor será a precisão na detecção de um evento ou no monitoramento de uma variável do ambiente. Ao se aproximar do alcance máximo (r_s) do sensor, essa precisão estará perto de zero.

$$DP(sr_i, p) = \begin{cases} 1, & d(sr_i, p) \leq r_l \\ (r_s - d)/(r_s - r_l), & r_l < d(sr_i, p) \leq r_s \\ 0, & c.c \end{cases} \quad (3a)$$

$$d(sr_i, p) = \sqrt{(p_x - sr_x)^2 + (p_y - sr_y)^2} \quad (3b)$$

Com base no alcance r_s do dispositivo, a área sob a curva da Figura 2(a) foi dividida em três sub-áreas definidas como Regiões de Qualidade de Sensoriamento (Q_S), sendo elas: qualidade Alta, Média e Baixa, sendo representadas, respectivamente, pelos valores $\{1, 2, 3\}$. A divisão dos intervalos pode ser compreendida através da Figura 2(b) e pelas Equação 4a e 4b.

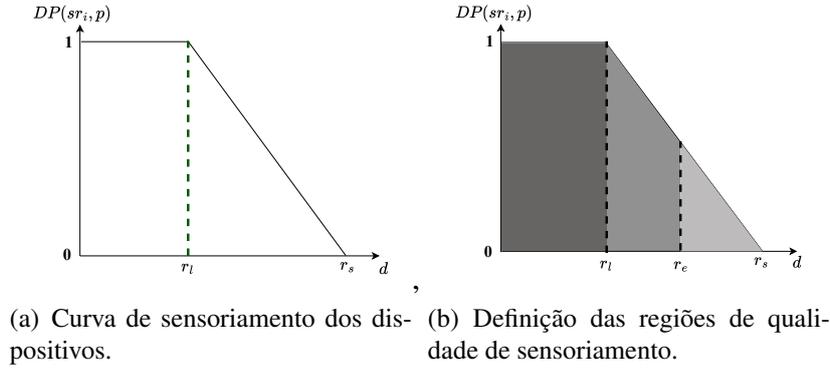


Figura 2. Representação do modelo de sensoriamento.

$$Q_S(sr_i, p) = \begin{cases} 1, & d(sr_i, p) \leq r_l \\ 2, & r_l < d(sr_i, p) \leq r_e \\ 3, & r_e < d(sr_i, p) \leq r_s \\ 0, & c.c \end{cases} \quad (4a)$$

$$r_e = r_l + \frac{(r_s - r_l)}{2} \quad (4b)$$

Essa representação, que caracteriza a precisão ou qualidade com que um dispositivo pode medir ou detectar um evento, pode ser aplicada não apenas a sensores escalares, mas também às câmeras atuando como sensores visuais. Como ilustrado na Figura 3(a), a região de cobertura de um sensor escalar apresenta uma estrutura simples e intuitiva, uma vez que as delimitações dos níveis de qualidade de sensoriamento são definidas exclusivamente pelo raio de sensoriamento (r_s) e as variáveis r_l e r_e . Em contrapartida, a modelagem da região de cobertura para as câmeras é mais complexa. Na Figura 3(b), observa-se que, devido à geometria do campo de visão das câmeras, a modelagem inclui as variáveis θ e α , que representam, respectivamente, o ângulo de abertura do campo de visão da câmera, em graus, e sua orientação.

3.3. Funções de *Fitness*

Após a descrição do modelo representativo para as RDI e para os dispositivos de monitoramento, nesta seção são descritas as funções de *fitness* utilizadas para a maximização dos critérios de *cobertura*, *alta conectividade* e *qualidade de sensoriamento* de uma RSSF construída a partir de um conjunto de sensores escalares e visuais. Essas funções são processadas posteriormente pelo algoritmo genético para avaliar a qualidade das soluções produzidas.

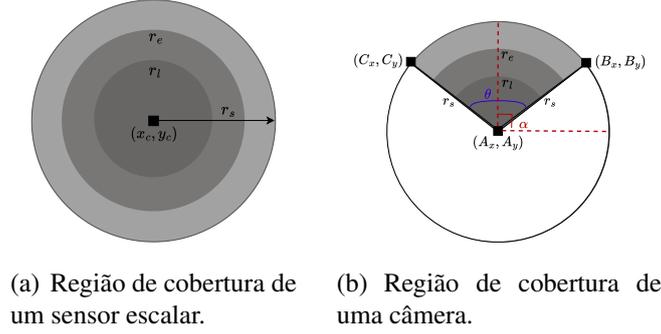


Figura 3. Região de cobertura dos sensores escalares e visuais.

3.3.1. Cobertura

Ao implantar um conjunto de dispositivos $Sr = \{sr_1, sr_2, sr_3, \dots, sr_N\}$ em uma RdI subdividida em AB, busca-se maximizar a quantidade de blocos monitorados por ao menos um sensor. Para isso, após o posicionamento do conjunto Sr , pode-se calcular a quantidade de ABs monitorados (AB_{sensed}) em relação ao total (AB_{total}). Entretanto, é necessário levar em consideração um aspecto específico: quando os sensores são posicionados próximos ao limiar ou à borda da RdI, os sensores podem cobrir áreas que não são relevantes para a aplicação, ou seja, que estão fora da RdI.

Para tratar esse problema, calcula-se o número de AB inválidos e aplica-se uma penalidade à função de *fitness* final: Para cada três ABs inválidos, um AB válido é desconsiderado na taxa de cobertura. A partir disso, sendo S_i a i -ésima solução gerada pelo algoritmo genético, a função de otimização f_1 avalia a cobertura de área dessas soluções, conforme descrito na Equação 5. É importante mencionar que o intervalo de f_1 corresponde a $[0, 1]$.

$$f_1(S_i) = \frac{(AB_{sensed} - \frac{AB_{invalid}}{3})}{AB_{total}} \quad (5)$$

3.3.2. Dispositivos em regiões de alta conectividade

A métrica $DPConn$ é utilizada como um parâmetro de qualidade de rede, a fim de garantir que os dispositivos de uma RSSF possuam acesso a um sinal de comunicação robusto, garantindo maior eficiência e integridade no processo de transmissão e recebimento de dados ao longo do tempo. Portanto, a segunda função de otimização (f_2) busca maximizar a taxa de dispositivos posicionados em regiões de alta conectividade (Sr_{inH}), ou seja, em AB com o nível de conectividade igual a 3, garantindo também que a seguinte expressão seja atendida: $Sr_{inH} > Sr_{inM} > Sr_{inL}$. Essa expressão assegura que o menor número possível de dispositivos seja posicionado em regiões de baixa conectividade (Sr_{inL}), enquanto a maioria é alocada em regiões de alta conectividade, seguida das regiões de média conectividade (Sr_{inM}).

A partir disso, temos a formulação de f_2 na Equação 6a, sendo o seu intervalo variando entre $[0, 1]$. Após a geração da solução S_i pelo algoritmo genético, verifica-

se a taxa de dispositivos implantados nas regiões de alta, média e baixa conectividade em relação ao total pré-estabelecido através do arquivo de configuração. Essas taxas são representadas, respectivamente, pelas Equações 6b, 6c e 6d.

$$f_2(S_i) = \begin{cases} Sr_{inH} * e^{-\gamma * Sr_{inH}}, & Sr_{inL} > Sr_{inH} \mid Sr_{inL} > Sr_{inM}, \\ Sr_{inH}, & c.c \end{cases} \quad (6a)$$

$$Sr_{inH} = Sensor_{NetHigh} \div Total_{sensors} \quad (6b)$$

$$Sr_{inM} = Sensor_{NetMedium} \div Total_{sensors} \quad (6c)$$

$$Sr_{inL} = Sensor_{NetLow} \div Total_{sensors} \quad (6d)$$

3.3.3. Qualidade de Sensoriamento

Além da busca pela maximização da cobertura e do posicionamento dos dispositivos em região de alta conectividade, também é necessário garantir a qualidade de sensoriamento ao longo da RdI. De acordo com o modelo de sensoriamento proposto, é possível que um determinado evento esteja ocorrendo em uma área com baixa qualidade de sensoriamento. Isso implica que, nessa região, a precisão com que o evento é detectado é baixa devido à distância ou outros aspectos como ruídos associados ao ambiente. Por essa razão, é necessário que se busque maximizar o número de áreas com alta qualidade de sensoriamento.

Para alcançar esse objetivo, é realizada a sobreposição das regiões de cobertura que estão próximas umas das outras. Desta forma, considerou-se que o nível Q_S do i-ésimo AB é dado pelo maior nível de qualidade sobreposto a essa área. Portanto, seja $Sr = \{sr_1, sr_2, sr_3, \dots, sr_N\}$ o conjunto de sensores que monitoram o mesmo AB_i , o $Q_S(AB_i)$ é dado pelo maior nível de qualidade imposto por um sensor do conjunto Sr . A Equação 7 apresenta formalmente essa definição.

$$Q_S(AB_i) = \max(Q_S(sr_j, p_{AB_i}), Q_S(sr_{j+1}, p_{AB_i}), \dots, Q_S(sr_n, p_{AB_i})) \quad (7)$$

A partir disso, como pode ser visto nas Equações 8a, 8b e 8c, para cada AB monitorado verifica-se o seu respectivo nível Q_S e realiza-se o cálculo da taxa de AB em cada um dos níveis em relação ao total de blocos monitorados. As funções *BlocksHS*, *BlocksMS* e *BlocksLS* percorrem o registro de blocos monitorados verificando se os mesmos possuem o nível Q_S desejado (*HS* = sensoriamento alto; *MS* = sensoriamento médio; *LS* = sensoriamento baixo).

$$AB_{wHS} = \frac{\sum_{i=1}^N BlocksHS(AB_{i_{sensed}})}{AB_{sensed}} \quad (8a)$$

$$AB_{wMS} = \frac{\sum_{i=1}^N BlocksMS(AB_{i_{sensed}})}{AB_{sensed}} \quad (8b)$$

$$AB_{wLS} = \frac{\sum_{i=1}^N BlocksLS(AB_{i_{sensed}})}{AB_{sensed}} \quad (8c)$$

Depois desse processo, pode-se calcular a função de *fitness* f_3 , demonstrada na Equação 9. Seu intervalo corresponde a $[0, 1]$. Perceba que f_3 possui a mesma estrutura da função f_2 , pois, como originalmente o comportamento de ambas é linear, então pode-se aproveitar a mesma composição, incluindo a função exponencial para a penalidade. Também, assim como em f_2 , mas agora em relação a f_3 , deseja-se que a seguinte expressão seja alcançada: $AB_{wHS} > AB_{wMS} > AB_{wLS}$. Garantindo que a maioria dos AB sejam monitorados por regiões de cobertura com alta qualidade de sensoriamento, seguido pelos AB com média, e por último, com baixa.

$$f_3(S_i) = \begin{cases} AB_{wHS} * e^{-\gamma * AB_{wHS}}, & AB_{wLS} > AB_{wHS} \\ AB_{wHS}, & AB_{wLS} > AB_{wMS}, \end{cases} \quad (9)$$

c.c

4. Resultados

A partir da modelagem apresentada, decidiu-se utilizar uma abordagem heurística baseada no uso do algoritmo genético multiobjetivo NSGA-II a fim de realizar o balanceamento entre os objetivos de interesse que estão expressos através dos critérios de otimização. Para definir os hiperparâmetros do algoritmo NSGA-II de forma a proporcionar o aumento do seu desempenho relacionado à geração de soluções ótimas da Fronteira de Pareto, foi utilizada uma abordagem sistemática conhecida como *Grid Search*. Essa abordagem consiste em definir um conjunto de valores para cada hiperparâmetro e, em seguida, avaliar a combinação desses diferentes valores a partir dos resultados produzidos pela execução do algoritmo genético [Yang and Shami 2020]. Foram avaliados diferentes valores para os seguintes hiperparâmetros: tamanho da população ($TP = \{100, 200\}$), taxa de cruzamento ($TC = \{70\%, 80\%, 90\%\}$), taxa de mutação ($TM = \{10\%, 20\%, 30\%\}$) e o número de gerações ($NG = \{250, 500, 750\}$).

Além de variar os hiperparâmetros, também foi decidido incluir na análise do *Grid Search*, o uso de dois métodos de cruzamento - *Simulated Binary Crossover (SBX)* e *Two-Point Crossover* - conjuntamente com o método *Polynomial Mutation* e Seleção por Torneio, formando assim duas versões de configuração para a execução do NSGA-II. O cenário de teste para o algoritmo NSGA-II foi simulado gerando uma RdI que apresentasse aspectos ideais de conectividade em uma região urbana, ou seja, uma RdI altamente conectada (a taxa de área coberta por redes sem fio precisa ser alta) e com redes uniformemente distribuídas ao longo da RdI. Observe na Figura 4 a RdI idealizada, sendo $ws_{city} = 8000m$, $hs_{city} = 5000m$, $ws_{AB} = 15$, $hs_{AB} = 15$, $AB_{total} = 177.489$ e $nb_C = 171.961$ (96.88%). Na área delimitada, foram implantadas 960 redes do tipo WiFi, 3 do tipo 4G e 28 do tipo LoRa.

Como a execução e análise dos resultados produzidos pelo algoritmo NSGA-II, finalizou-se o processo de *Grid Search*, sendo definido que os operadores genéticos *Polynomial Mutation*, *Two-Point Crossover* e Seleção por Torneio seriam utilizados em todos os outros cenários avaliados ao longo desta pesquisa, em conjunto com os seguintes valores de hiperparâmetros: Taxa de Mutação - 0.1; Taxa de Cruzamento - 0.9; Tamanho da População - 200; Número de Gerações (critério de parada) - 750.

Com o objetivo de avaliar a qualidade do posicionamento efetuado pelo algoritmo NSGA-II a partir dos operadores genéticos e hiperparâmetros escolhidos, foi selecionada uma solução que apresentasse maior equilíbrio entre as três funções de *fitness*.

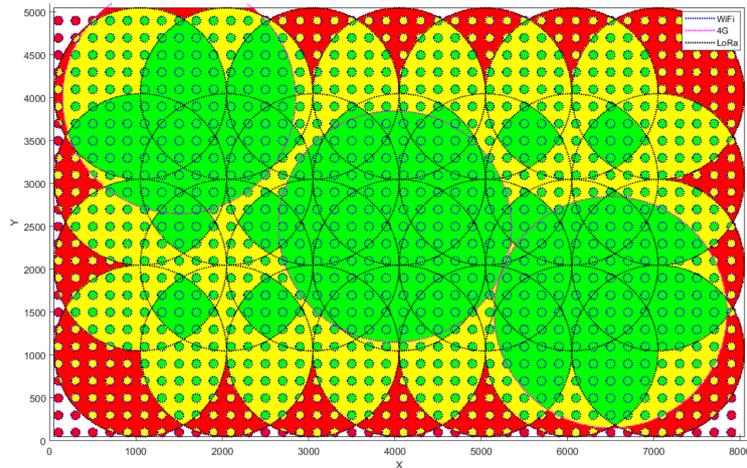


Figura 4. Representação da Rdl gerada para aplicação da estratégia *Grid Search*.

Diante disso, foi escolhida a solução gerada com $F_1(s) = 0.88792$, $F_2(s) = 0.54075$ e $F_3(s) = 0.48324$. Como forma de avaliar o posicionamento a partir do processamento da solução escolhida, foram definidos os seguintes aspectos a serem examinados: disposição dos dispositivos ao longo da Rdl; taxa de cobertura; níveis de sobreposição das áreas monitoradas; e níveis de qualidade de sensoriamento. Na Figura 5(a), encontra-se a implantação dos dispositivos de monitoramento sobre a Rdl ideal. Os pontos em cor laranja representam os sensores escalares, enquanto os pontos em azul, as câmeras. Nota-se que o NSGA-II conseguiu dispersar satisfatoriamente os 8000 dispositivos configurados, abrangendo assim toda a área da Rdl.

A partir desse posicionamento, 54.075% dos dispositivos foram implantados em regiões de alta conectividade, 30.925% em regiões de média e 15% em regiões de baixa conectividade. Isso mostra que foi garantido que mais da metade dos dispositivos possua um nível robusto de conectividade de forma a realizar suas tarefas de comunicação com eficiência, segurança e integridade dos dados.

Levando em consideração que, segundo [Fei et al. 2017], a cobertura de uma RSSF é o aspecto mais importante a ser avaliado, podemos dizer que, especificamente para este estudo, o posicionamento efetuado alcançou um bom resultado, pois 89.55% da área pertencente à Rdl está sendo monitorada. Isso pode ser visto na Figura 5(b). As regiões em cor azul representam áreas que possuem conectividade, seja em nível alto, médio ou baixo, mas não estão sendo monitoradas por nenhum dispositivo, enquanto as pequenas regiões em branco nos limiares da Rdl são áreas sem conexão e sem monitoramento. Também podemos analisar os níveis de sobreposição em cada AB da Rdl. Veja a Figura 5(c). Foi verificado que 25.130% dos ABs estão sendo monitorados 1 dispositivo; 28.732% por 2 dispositivos; 22.946% por 3 dispositivos; e 23.192% por mais de 3. Devido à proximidade das taxas, percebe-se que, sem prejudicar a taxa de cobertura, o NSGA-II conseguiu alcançar uniformidade para o número de dispositivos cobrindo cada AB.

Analisando através da Figura 5(d) a qualidade de sensoriamento imposta pelo posicionamento dos dispositivos, constatou-se que 48.324% dos ABs apresentaram nível alto de qualidade, enquanto 33.794% apresentaram nível médio e apenas 17.881% nível baixo. Isso demonstra que a expressão $AB_{wHS} > AB_{wMS} > AB_{wLS}$ descrita na Seção

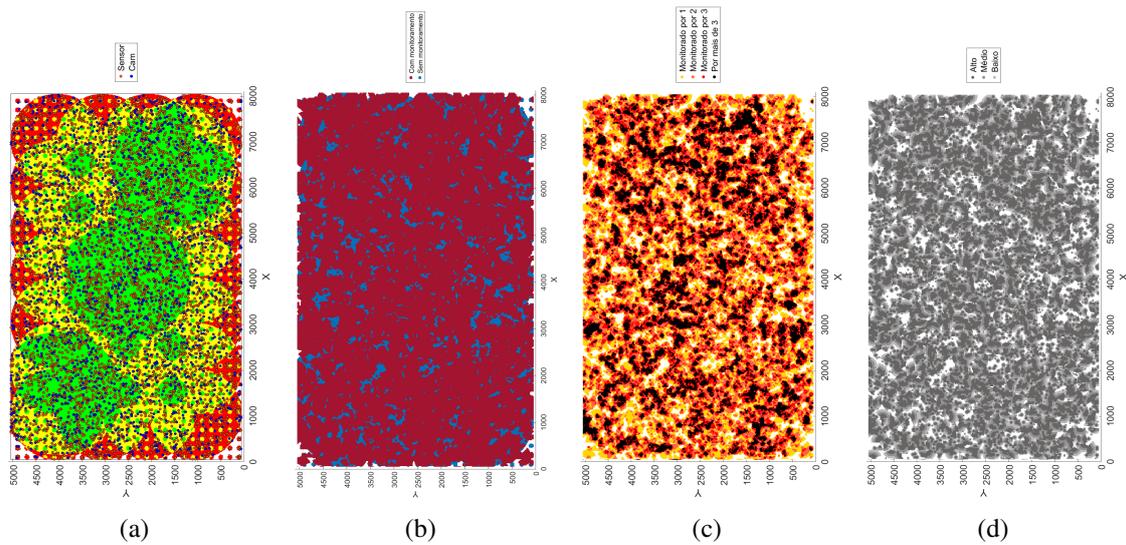


Figura 5. Comparativo dos resultados no Cenário Ideal (*Grid Search*).

3.3.3 foi alcançada, garantindo que, em grande parte da área monitorada, a detecção de eventos não seja prejudicada por aspectos como distância, ruídos do ambiente, temperaturas extremas ou mesmo o fim da vida útil de um dos dispositivos que monitora em conjunto com outros, o respectivo bloco.

Após a aplicação do método *Grid Search* e da análise dos resultados obtidos, foi possível estabelecer para o algoritmo NSGA-II um conjunto de operadores genéticos e hiperparâmetros que, diante dessa análise inicial, comprovou ser eficaz na busca por soluções que atendem satisfatoriamente aos critérios de otimização impostos.

5. Conclusão

A metodologia proposta demonstrou eficácia ao integrar objetivos múltiplos como cobertura, conectividade e qualidade de sensoriamento em um processo único e coeso. Diferentemente de abordagens existentes, que frequentemente tratam esses objetivos de forma isolada ou parcial, a abordagem apresentada permitiu alcançar um equilíbrio satisfatório entre a maximização da área monitorada, distribuição adequada dos sensores e níveis consistentes de redundância e qualidade nas áreas críticas. Tal abordagem favorece significativamente a robustez das redes colaborativas de sensores em contextos urbanos, promovendo uma resposta ágil e eficaz diante de situações emergenciais.

Como trabalhos futuros, pretende-se avaliar o desempenho do método proposto em cenários urbanos reais, considerando características dinâmicas e aspectos de mobilidade, interferências e falhas nos dispositivos sensores. Por fim, é relevante investigar o impacto da inclusão de critérios adicionais como consumo energético e custo financeiro dos dispositivos, bem como explorar a aplicação de outras técnicas meta-heurísticas para comparação e validação da robustez da metodologia proposta frente a diferentes configurações e escalas.

Referências

Benatia, M. A., Sahnoun, M., Baudry, D., Louis, A., El-Hami, A., and Mazari, B. (2017). Multi-objective wsn deployment using genetic algorithms under cost, coverage, and

- connectivity constraints. *Wireless Personal Communications*, 94(4):2739–2768.
- Binh, H. T. T., Hanh, N. T., Quan, L. V., and Dey, N. (2018). Improved cuckoo search and chaotic flower pollination optimization algorithm for maximizing area coverage in wireless sensor networks. *Neural Computing and Applications*, 30(7):2305–2317.
- Bouzzid, S. E., Serrestou, Y., Raoof, K., Mbarki, M., Omri, M. N., and Dridi, C. (2020). Wireless sensor network deployment optimisation based on coverage, connectivity and cost metrics. *International Journal of Sensor Networks*, 33(4):224–238.
- Chen, Y.-N., Lin, W.-H., and Chen, C. (2020). An effective sensor deployment scheme that ensures multilevel coverage of wireless sensor networks with uncertain properties. *Sensors*, 20(7).
- Coelho, G. A. A., Jesus, T. C., and Costa, D. G. (2023). Urban emergency detection system using hierarchical, collaborative and configurable wireless sensor networks. In *XIII Brazilian Symposium on Computing Systems Engineering (SBESC)*, pages 1–6.
- Costa, D. G., Rangel, E., Peixoto, J. P. J., and Jesus, T. C. (2019). An availability metric and optimization algorithms for simultaneous coverage of targets and areas by wireless visual sensor networks. In *2019 IEEE 17th International Conference on Industrial Informatics (INDIN)*, volume 1, pages 617–622.
- El-Sherif, M., Fahmy, Y., and Kamal, H. (2018). Lifetime maximisation of disjoint wireless sensor networks using multiobjective genetic algorithm. *IET Wireless Sensor Systems*, 8(5):200–207.
- Fei, Z., Li, B., Yang, S., Xing, C., Chen, H., and Hanzo, L. (2017). A survey of multi-objective optimization in wireless sensor networks: Metrics, algorithms, and open problems. *IEEE Communications Surveys & Tutorials*, 19(1):550–586.
- Hanh, N. T., Binh, H. T. T., Hoai, N. X., and Palaniswami, M. S. (2019). An efficient genetic algorithm for maximizing area coverage in wireless sensor networks. *Information Sciences*, 488:58–75.
- Jesus, T. C., Costa, D. G., and Portugal, P. (2019). Wireless visual sensor networks redeployment based on dependability optimization. In *2019 IEEE 17th International Conference on Industrial Informatics (INDIN)*, volume 1, pages 1111–1116.
- Jesus, T. C., Costa, D. G., Portugal, P., Vasques, F., and Ferreira, W. A. (2023). Dependability and quality-aware connectivity in smart cities applications. In *2023 IEEE International Smart Cities Conference (ISC2)*, pages 1–7.
- Rangel, E. O., Costa, D. G., and Loula, A. (2019). On redundant coverage maximization in wireless visual sensor networks: Evolutionary algorithms for multi-objective optimization. *Applied Soft Computing*, 82:105578.
- Wu, H., Liu, Z., Hu, J., and Yin, W. (2020). Sensor placement optimization for critical-grid coverage problem of indoor positioning. *International Journal of Distributed Sensor Networks*, 16(12):1550147720979922.
- Yang, L. and Shami, A. (2020). On hyperparameter optimization of machine learning algorithms: Theory and practice. *Neurocomputing*, 415:295–316.